

## 有明海における赤潮発生予測に適した畳み込みニューラルネットワークの開発 Development of a Convolutional Neural Network for Predicting Red Tide Occurrence in the Ariake Sea

田畑俊範\*, 長野鈴\*\*, 原田昌佳\*, 尾崎彰則\*\*\*  
Toshinori Tabata\*, Suzu Nagano\*\*, Masayoshi Harada\*, Akinori Ozaki\*\*\*

1. はじめに 有明海では赤潮の頻発化に起因した漁業被害が課題であり、事前の赤潮発生の予測技術の開発が急務である。これに対し、機械学習を援用したモデル開発が進められているが、その手法は未だ確立されていない。本研究では、効率的に特徴量の抽出が可能な畳み込みニューラルネットワークモデル (CNN) に着目し、赤潮発生時の海域周辺の環境の特徴抽出に向けた同モデルの適用可能性について検討した。

2. CNN モデル概要 CNNは畳み込み演算を行うことで、3次元データの特徴量の抽出に優れている。畳み込み演算とは、入力された3次元データとフィルタと呼ばれる3次元の重みの内積をとる処理である。一度の畳み込みで用いるフィルタの数をフィルタの種類数、フィルタの要素数をフィルタサイズと呼ぶ。本研究では、環境データの時空間情報を項目ごとに2次元マップ化することで、

〈地点情報×時間情報×観測項目〉の3次元データを作成し、CNNによる赤潮発生時における海域周辺の環境の経時的な特徴抽出を試みた。構築したモデルは、有明海沿岸4県(福岡県、佐賀県、熊本県、長崎県)の赤潮発生を予測するモデルである。教師データの入力変数は、Fig.1に示すAMeDAS観測地点の気象データ4項目(日平均気温、日降水量、日照時間、日平均風速)と潮汐観測地点における日最大潮差を使用した。これらの各項目について、Fig.2に示すように現時点のW日前から前日までの1日毎の値を観測地点毎に縦横に並べた2次元マップとした。教師データの出力変数は、各県の赤潮の発生有無を{0, 1}で表した。開発したCNNモデルは、2層の畳み込み層、1層のプーリング層、3層の全結合層の構造をもつ。全結合層の活性化関数には、シグモイド関数を使用したため、出力値は赤潮の発生状況を[0, 1]の連続的変数で表現する。本研究では、閾値処理によって赤潮の発生有無を判断し、その閾値に0.3と0.5を用いた。対象期間は1997年から2023年

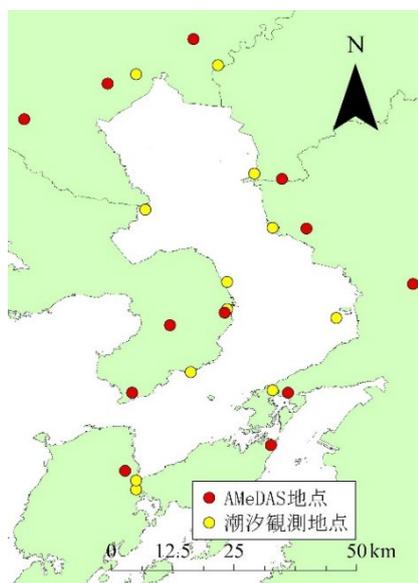


Fig.1 AMeDAS観測地点および潮汐観測地点

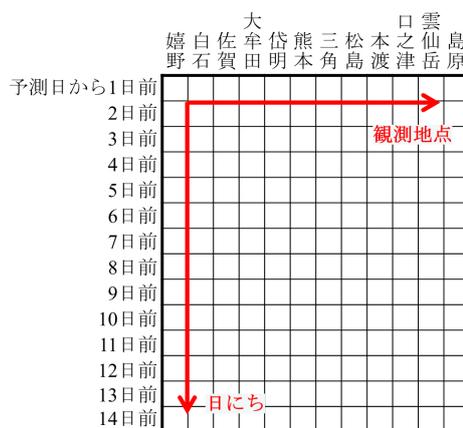


Fig.2 気象データの2次元マップ化の概略図 (W=14)

\*九州大学大学院農学研究院 / Faculty of Agriculture, Kyushu University, \*\*九州大学農学部 (卒業生) / Faculty of Agriculture, Kyushu University (Graduate), \*\*\*九州大学 熱帯農学研究センター / Institute of Tropical Agriculture, Kyushu University ; キーワード : 水環境, 有明海, 赤潮予測, CNN

とし、10分割交差検証によりモデルの予測精度を評価した。

**3. 結果と考察** 結果の一例として、Table 1 にデータ日数  $W$  を変化させた際の予測結果の混合行列から求めた Precision, Recall, Accuracy を示す。また、Fig.3 に  $W$  を変更した際のモデル出力値の頻度分布を示す。これは、予測精度が高い理想的なモデルが開発された場合、両端の 0 と 1 付近に分布が集中する谷型の形状を示す。Table 1 より、赤潮を漏れなく予測できているかの指標である Recall を重視した場合、 $W$  は 7 日と設定することが適切であると考えられる。しかし、Fig.3 の分布をみると、分布の形状に凹凸が目立ちモデルが良好に学習できていないと考えられる。 $W$  を大きくするほど、出力値は谷型の形状へと変化した。ハイパーパラメータの最適値の決定には、Precision, Recall, Accuracy の精度指標に加え、出力値の頻度分布形状も考慮する必要がある。フィルタの種類数を変化させた際に、精度指標や出力結果の頻度分布の変化に関連性は見られなかったため、それぞれが良好な結果を示した 6 種類を採用した。フィルタサイズは、小さくするほど精度指標は向上し、出力値の頻度分布も谷型の傾向が強まった。以上の結果から、 $W$  を 28 日間、フィルタの種類数を 6 種類、フィルタサイズを  $2 \times 2$  としたモデルを採用し、その予測精度を Table 2 に示す。また、Fig.4 に採用したモデルの出力値の頻度分布を示す。予測精度は全体的に高く、頻度分布でも両端が高い谷型の形状を示し、十分な精度で予測していた。以上より、赤潮発生時における海域周辺の環境の特徴抽出には、CNN が有効であることが示された。本研究では、データ日数、フィルタ種類数、フィルタサイズについて検討したが、さらに畳み込み層の層数や使用する観測地点や観測項目について検証を行うことで予測精度が向上することが期待される。

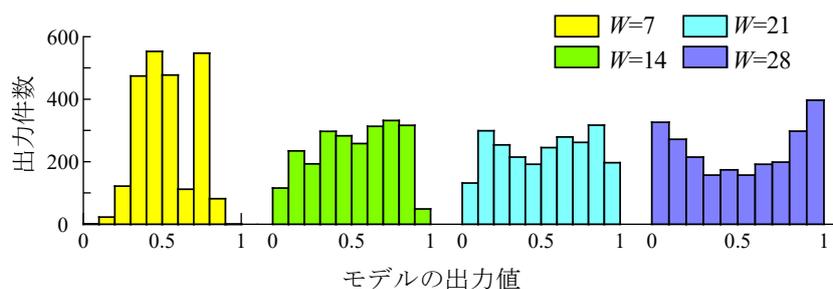
**4. おわりに** 事前の赤潮発生の予測技術の開発に向けた CNN の適用可能性について検討し、赤潮発生予測モデルの開発を行った。その結果、十分な精度で赤潮発生を予測可能なモデルの開発に成功し、赤潮発生時における海域周辺の環境の経時的な特徴抽出に CNN が有効であると示された。今後の方針として、畳み込み層の層数の変更や、観測地点の検討等、モデル構造の改善により、モデル精度の向上に取り組む。

**Table 1** データ日数  $W$  を変更した際の予測精度

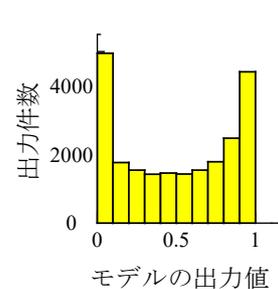
$W$		赤潮発生	
		閾値 0.3	閾値 0.5
7	Precision	0.544	0.697
	Recall	0.980	0.682
	Accuracy	0.561	0.680
14	Precision	0.596	0.681
	Recall	0.884	0.693
	Accuracy	0.628	0.671
21	Precision	0.616	0.666
	Recall	0.843	0.694
	Accuracy	0.644	0.659
28	Precision	0.630	0.662
	Recall	0.797	0.662
	Accuracy	0.650	0.648

**Table 2** モデルの予測精度

	赤潮発生 閾値 0.3	赤潮発生 閾値 0.5
Precision	0.636	0.672
Recall	0.793	0.688
Accuracy	0.655	0.661



**Fig.3** データ日数  $W$  を変更した際の出力値の頻度分布



**Fig.4** 出力値の頻度分布